УДК 004.93

А.М. Ахметшин, К.А. Ахметшин
Днепропетровский национальный университет, г. Днепропетровск, Украина
akhmlu@mail.ru

Выделение скрытых областей слабоконтрастных изображений методом ортогональной декомпозиции

Рассмотрены информационные возможности метода анализа слабоконтрастных изображений. Суть метода основана на разделении анализируемых компонент многопараметрового (мультиспектрального) изображения на ортогональные составляющие, при этом в составляющих высокого порядка выделяются области, первоначально неразличимые на исходных изображениях. Представлены результаты численного моделирования и реальной проверки работоспособности метода.

Введение

Задача выделения визуально неразличимых областей слабоконтрастных изображений (как обычных, так и многопараметровых) имеет большое прикладное значение в таких областях, как медицинская диагностика (идентификация радиологических, ультразвуковых и оптических изображений), дистанционное зондирование Земной поверхности и анализ изображений геофизических полей. Наличие подобной проблемы обусловлено недостаточной чувствительностью человеческого глаза, воспринимающего, в соответствии с законом Вебера, лишь 2% перепадов яркости, причем это значение существенно зависит от окружающего фона, причем сложность задачи существенно возрастает с увеличением числа диапазонов (параметров) в мультиспектральных изображениях.

Целью работы является демонстрация информационных возможностей метода ортогональной декомпозиции применительно к решению задач выделения визуально неразличимых участков слабоконтрастных изображений.

Ортогонализирующие преобразования

Для определенности первоначально рассмотрим случай, связанный с анализом многопараметрового (например, цветного) изображения $\{I(x, y, n)\}$, где n – число параметров (диапазонов), соответствующих каждому пикселю (x, y). Если представить анализируемый ансамбль изображений {I} в виде прямоугольной матрицы A размерностью $(M \times N) \times n$, где M и N – число пикселей вдоль осей «x» и «y» соответственно, то можно произвести сингулярное разложение матрицы А на основе выражения

$$G = UWV^T, \tag{1}$$

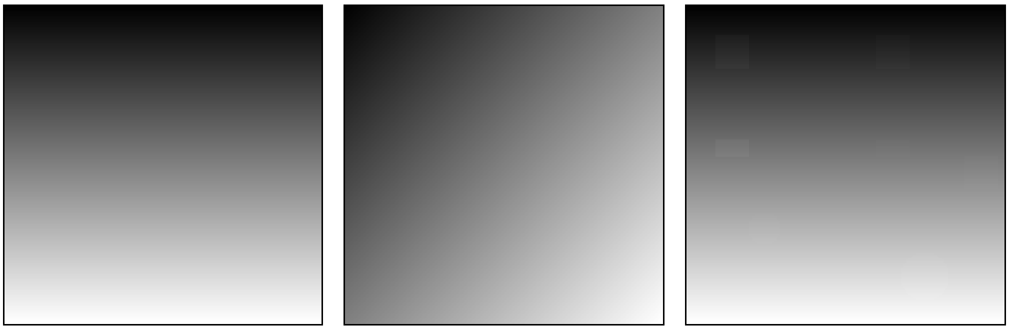
где $U = [U_1 U_2 ... U_n]$ – матрица сингулярных векторов размерностью $((M * N) \times n)$, формирующих ортонормированный базис пространства, натянутого на столбцы матрицы G, формирующая базис «собственных изображений» (СИ) [1]; W – диагональная матрица, элементы которой w_i $(i = 1,..., n)$ являются сингулярными числами матрицы G,

причем $w_1 \geq w_2 \geq ... \geq w_n \geq 0$. Они являются собственными значениями матрицы $G^T G$, а V представляет собой ортогональную матрицу размерностью ($n \times n$). На основе анализа спектра нормированных сингулярных чисел $\hat{w}_i$ базируются основные методы компрессии (сокращения избыточности) ансамбля анализируемых изображений {I}, основанные на том обстоятельстве, что если

$$\sum_{i=1}^{k} \hat{w}_i \geq D, \tag{2}$$

где D – критическое значение, равное, например, 95% или 99%, $k \leq n$. Физический смысл выражения (2) базируется на том обстоятельстве [2], что «собственные изображения», синтезированные из столбцов матрицы U (т.е. $U_1,...,U_k$), обеспечивают D% всей информации, заложенной в исходном ансамбле {I}.

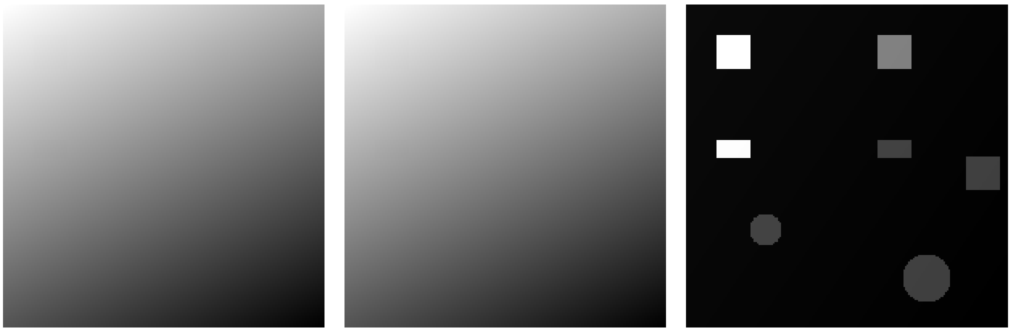
На рис. 1 представлена численная модель трехдиапазонного изображения.



1 2 3

Рисунок 1 – Численная модель трехдиапазонного изображения

Характерной особенностью рассматриваемого примера является то обстоятельство, что на третьем изображении расположено семь слабоконтрастных участков, из которых визуально идентифицируются только три, а четыре являются невидимыми. На рис. 2 представлены «собственные изображения» анализируемого ансамбля, спектр нормированных сингулярных чисел которого равен: $\hat{w}_1$=85,3405%; $\hat{w}_2$=14,6582%; $\hat{w}_3$=0,0012%. Из рассмотрения спектра сингулярных чисел следует, что первое «СИ» содержит более 99% информации, содержащейся в трех исходных изображениях, т.е. в соответствии с рекомендуемым теоретическим подходом (2) можно ограничиться только анализом U_1.



1 2 3

Рисунок 2 – «Собственные изображения» ансамбля, представленного на рис. 1

Однако из рассмотрения рис. 2 видно, что визуальная идентификация всех семи слабоконтрастных участков возможна лишь на третьем СИ, содержащем лишь 0,0002% исходной информации. Из рассмотренного примера вытекают два практических важных вывода.

1. Для обнаружения и идентификации слабоконтрастных и визуально неидентифицируемых участков необходимо анализировать весь ансамбль синтезированных СИ.

2. Для информационной значимости ансамбля СИ необходимо, чтобы исходные изображения были высококачественными, поскольку в противном случае большая часть СИ будет соответствовать шумовым компонентам [3], не поддающимся анализу.

Метод сингулярного разложения (1) обеспечивает алгебраическую ортогонализацию. Возможен и другой, статистический, подход, базирующийся на синтезе ансамбля «независимых изображений» – метод независимых компонент (МНК) [4].

МНК – это метод нахождения скрытых факторов или компонент в многомерных данных, особенность которого в том, что он позволяет выделять статистически независимые составляющие. В принципе в классическом факторном анализе [5] также требуется, чтобы выделенные факторы были статистически независимы. Однако при этом предполагается, что анализируемые данные имеют гауссово распределение, которое редко встречается на практике.

Основной принцип нахождения независимых компонент базируется на максимизации негауссовости анализируемого статистического распределения. Из центральной предельной теоремы следует, что сумма независимых случайных переменных стремится к нормальному распределению. Тогда сумма даже двух независимых случайных переменных обычно будет иметь распределение более близкое к нормальному, чем распределение любой из двух исходных случайных последовательностей. Задачу обычно называют задачей слепого разделения источников, подчеркивая, что единственной информацией для восстановления входа является реализация вектора наблюдений x.

В МНК предполагается, что анализируемые случайные переменные $x_1,...,x_n$ могут быть представлены в виде линейной комбинации случайных переменных $s_1,...,s_k$ как

$$x_i = a_{i1}s_1 + a_{i2}s_2 + ... + a_{ik}s_k \,;\, i = 1,2,...,n; k \le n\,, \tag{3}$$

где a_{ij} – некоторые неизвестные нам действительные коэффициенты; s_j – рассматриваются как статистически взаимно независимые скрытые компоненты. В векторно-матричной форме записи уравнение (3) представимо в виде $x = As$.

Основные допущения МНК базируются на трех основных предположениях.

1. Независимые компоненты предполагаются статистически независимыми, т.е. совместная плотность распределения вероятностей $p(s_1, s_2,..., s_k)$ может быть факторизована в виде

$$p(s_1, s_2,..., s_k) = p(s_1)p(s_2)...p(s_k).$$

2. Независимые компоненты должны иметь негауссово распределение и приблизительно идентичные распределения. Поэтому если искомые компоненты имеют гауссово распределение, то реализация МНК невозможна.

3. Неизвестная матрица A может быть инвертирована, т.е. возможно обращение уравнения (3)

$$s = A^{-1}x.$$

Первое из предположений является гораздо более мощным по сравнению с требованием некоррелированности (как в методе главных компонент). Некоррелированность (в случае произвольного распределения плотностей вероятностей) не означает

статистической независимости, в то время как если, например, две переменные s_1 и s_2 статистически независимы, то любые их нелинейные преобразования типа $g(s_1)$ и $h(s_2)$ будут одновременно и некоррелированными.

Для данного вектора x задача сводится к поиску разделяющей матрицы B, такой, что исходный вектор s может быть получен из выходного вектора y (рис. 3). Это значит, что решение можно представить в виде $y = Bx = BAs$. Если обозначить одну из строк матрицы B как b, то линейная комбинация $b^T x$ будет эквивалентна одной из независимых компонент.

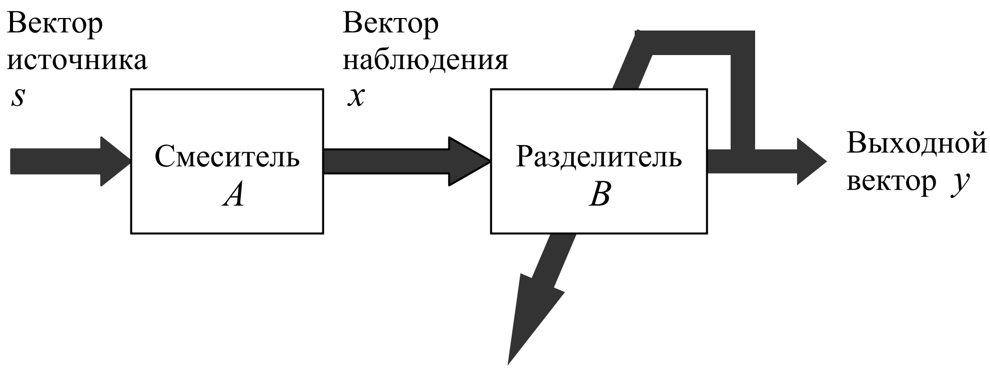


Рисунок 3 – Схема метода независимых компонент
(«слепого разделения источников»)

Проблема состоит в том, как воспользоваться выводами центральной предельной теоремы для нахождения b? На практике мы не можем точно определить вектор b, так как нам ничего не известно о матрице A. Все упирается в необходимость нахождения аппроксимационного решения, заключающегося в выборе такого вектора b, который бы максимизировал негауссовость распределения $b^T x$, дающего одну из независимых компонент.

Обычно в этой задаче предполагается, что входной сигнал имеет нулевое среднее значение, что гарантирует нулевые средние для x и выходного вектора.

Классической мерой негауссовости является кумулянт 4-го порядка, или эксцесс

$$\gamma_2 = E\{x^4\} - 3\left[E\{x^2\}\right]^2, \tag{4}$$

где $E\{x^n\}$ – n-й математический момент.

Однако он является весьма чувствительным к влиянию шумовых факторов. По этой причине в экспериментальных исследованиях, в качестве меры негауссовости, можно использовать значение энтропии. Энтропия случайного вектора s с плотностью распределения $p(s)$ определяется как

$$H(s) = -\int p(s) \log p(s) ds\,. \tag{5}$$

Значение энтропии для МНК обусловлено фундаментальным выводом теории информации – гауссовы переменные имеют наибольшую энтропию (т.е. наибольшую непредсказуемость) среди всех случайных переменных с эквивалентными дисперсиями. Практически именно это обстоятельство и означает, что значение энтропии может быть использовано в качестве меры негауссовости.

Определение матрицы B достигается путем максимизации значения отрицательной энтропии $H(S)$ в предположении, что $S = f(s)$, где f рассматривается как аппроксимирующая функция распределения независимых компонент.

Таким образом, структура использованного алгоритма МНК включает в себя следующие этапы.

1. Центрирование исходных данных для обеспечения нулевых средних.

2. Проведение предварительного декоррелирующего преобразования с определением значимого числа главных компонент, что позволяет минимизировать влияние шумовых факторов для последующего анализа (декоррелирующее преобразование входит как составная часть в МНК).

3. Инициализация начального значения матрицы B_0 случайными значениями с единичной дисперсией.

4. Максимизация значения неотрицательной энтропии методом сопряженного градиента – в результате итерационного процесса находится оптимальная, с точки зрения критериев МНК, матрица B.

5. Нахождение значения независимых компонент на основании уравнения (3), число которых совпадает с числом использованных главных компонент.

На рис. 4 представлены три «независимых изображения», синтезированных из исходного ансамбля на рис. 1.



Рисунок 4 – «Независимые изображения» ансамбля на рис. 1, синтезированные на основе метода независимых компонент

Из рассмотрения рис. 4 видно, что в отличие от метода сингулярного разложения (рис. 2) «аномальные» участки выделились на всех трех синтезированных изображениях. На рис. 5 представлены результаты ортогональной декомпозиции цветного RGB дерматологического изображения (рак кожи).

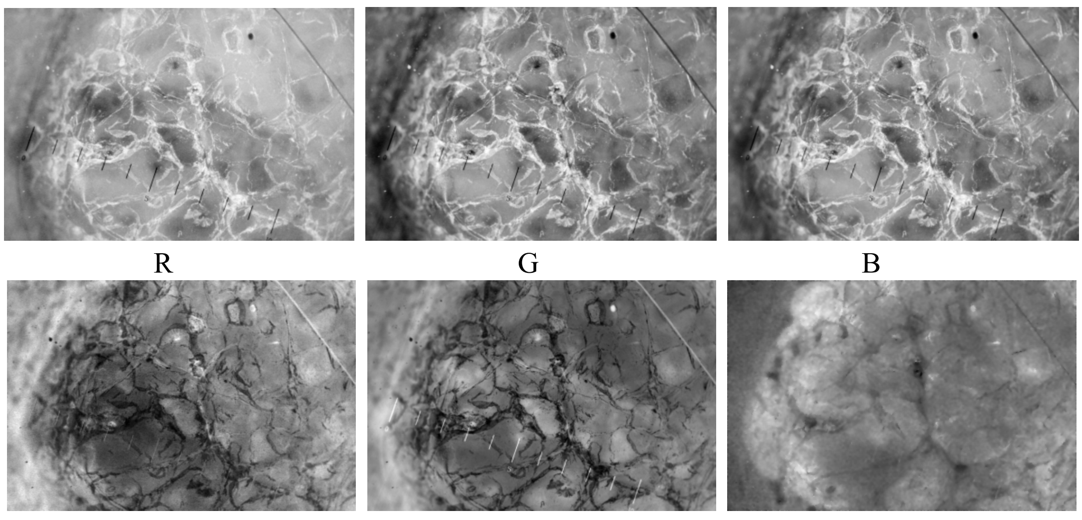
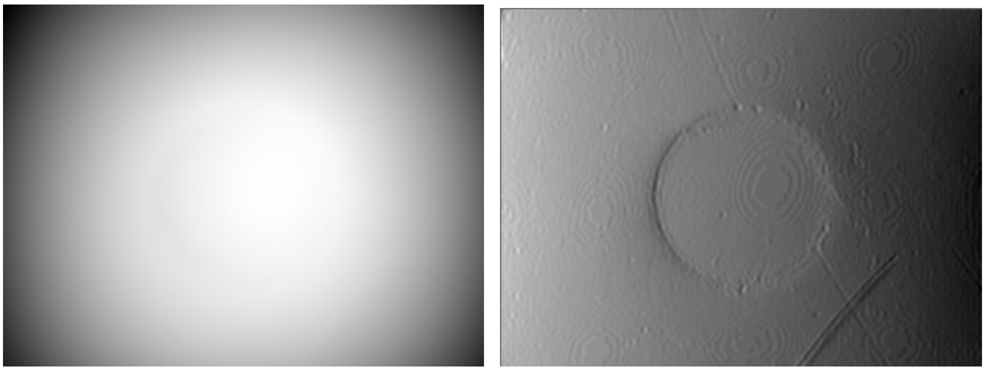


Рисунок 5 – Дерматологическое цветное изображение: верхний ряд – RGB компоненты оригинала; нижний ряд – синтезированные методом независимых компонент новые изображения

Здесь, как и в случае цифровой модели при использовании метода сингулярного разложения, «скрытая» информация выделилась на третьем синтезированном изображении. Его диагностическая значимость остается под вопросом, поскольку результат явился неожиданным для самих врачей.

Тот факт, что для «тонкого» визуального анализа необходимо использовать весь ансамбль синтезированных «собственных» или «независимых» изображений, открывает возможность повышения чувствительности визуального анализа и обычных (однопараметровых) слабоконтрастных изображений, базируясь на идее их автоморфного отображения [6], [7].

На рис. 6 а) представлено изображение оптического излучения из конца оптоволоконного кабеля.

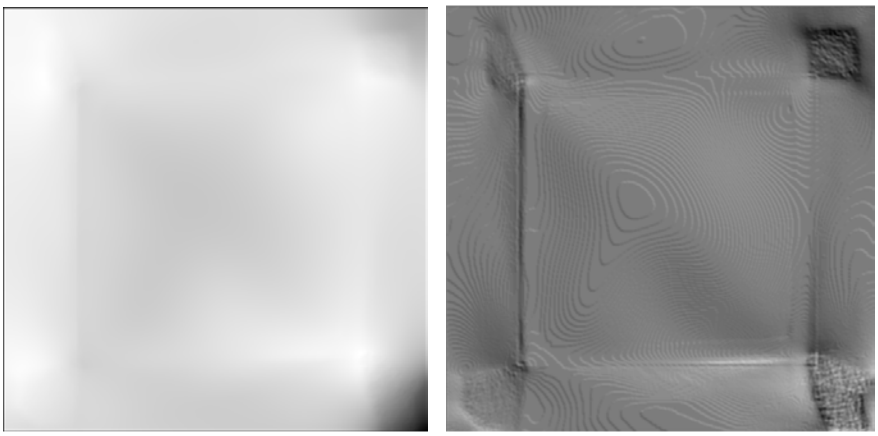


а) б)

Рисунок 6 – Изображение оптического излучения из конца оптоволоконного кабеля: а) оригинал; б) второе «собственное изображение» автоморфного отображения оригинала

Из рассмотрения рис. 6 б) видно, что на втором «собственном изображении» выделились особенности топологии рис. 6 а), а также скрытая деталь, расположенная в нижнем правом углу изображения.

На рис. 7 а) представлено инфракрасное изображение работающей интегральной микросхемы.



а) б)

Рисунок 7 – Инфракрасное изображение работающей микросхемы: а) оригинал; б) третье «независимое изображение»

Из рассмотрения рис. 7 б) видно, что, как и в случае оптического изображения на рис. 6, особенности анализируемого изображения выделились на третьем «независимом изображении» автоморфного отображения рис. 7 а). В данном случае применение как МНК, так и сингулярного разложения показало идентичные результаты.

Заключение

На основании проведенных исследований можно сделать следующие выводы.

1. Применение метода ортогональной декомпозиции как многомерного ансамбля, так и обычного (однопараметрового) слабоконтрастного изображения позволяет выделять визуально неразличимые скрытые участки.
2. Метод сингулярного разложения и метод независимых компонент можно считать не конкурирующими, а дополняющими друг друга, поскольку метод сингулярного разложения является намного более простым в вычислительном отношении по сравнению с методом независимых компонент.
3. Применение метода ортогональной декомпозиции предъявляет повышенные требования к качеству (помехоустойчивость и точность регистрации) исходных изображений.

Литература

1. Форсайт Д. Компьютерное зрение: современный подход / Д. Форсайт, Ж. Понс ; [пер. с англ. А.В. Назаренко, И. Ю. Дорошенко]. – М. ; СПб. ; К : Вильямс, 2004. – 926 с.
2. Фукунага К. Введение в статистическую теорию распознавания образов / Фукунага К. ; [пер. И.Ш. Торговицкого] ; под. ред. Ф.Ф. Дорофеюка. – М. : Наука, 1979. – 367 с.
3. Ахметшина Л.Г. Адаптивная фильтрация шумов в сигналах и изображениях: метод селективного сингулярного разложения автоморфного отображения / Л.Г. Ахметшина // Искусственный интеллект. – 2005. – № 3. – С. 328-335.
4. Hyvarinen A. Independent Component Analysis / Hyvarinen A., Karhunen J., Oja E. – N.Y. : John Wiley & Sons Inc., 2001. – 354 p.
5. Иберла К. Факторный анализ / Иберла К. ; [пер. В.М. Ивановой]. – М. : Статистка, 1980. – 398 с.
6. Ахметшина Л.Г. Повышение разрешающей способности изображений геофизических полей на основе метода многомерной ортогональной адаптивной кластеризации / Л.Г. Ахметшина // Науковий Вісник Національного гірничого університету. – 2003. – № 10. – С. 35-38.
7. Ахметшина Л.Г. Повышение чувствительности анализа рентгеновских снимков методом автоморфного отображения в базисе собственных изображений / А.М. Ахметшин, Л.Г. Ахметшина // Клиническая информатика и телемедицина. – 2008. – Т. 4, № 5. – С. 30-36.

О.М. Ахметшин, К.О. Ахметшин

Виділення прихованих ділянок низькоконтрастних зображень методом ортогональної декомпозиції

Розглянуто інформаційні можливості нового методу аналізу низькоконтрастних зображень. Суть методу полягає у розділенні аналізованих компонент багатопараметрового зображення на ортогональні складові, при цьому на складових більш високого порядку виділяються ділянки, невидимі на первісних зображеннях. Представлені результати реальної перевірки працездатності методу.

A.M. Akhmetshyn, K.A. Akhmetshyn

Hidden Domains Extraction of Low Contrast Images by Means of Orthogonal Decomposition Method

Information possibilities of a new method low contrast images analysis are considered. The main idea of the method is founded on separation of analyzed image on orthogonal components. For solution of this problem in the article were used two approaches: the first one is based on using the singular value decomposition (it is an algebraic method) and the second one is based on independent component method. The last provides the stochastic orthogonalization. Hidden domains of analyzed image are separated on orthogonalyzed image of high order. The results of real testing of the method possibilities are presented. The ones had shown that both methods are complement each other.

Статья поступила в редакцию 21.06.2010.